

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOFIZIČKI ODSJEK

Katarina Vinković

Integralne skale u prizemnom
atmosferskom sloju za buru

Diplomski rad

Zagreb, 2017.

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
GEOFIZIČKI ODSJEK

SMJER: METEOROLOGIJA I FIZIČKA OCEANOLOGRAFIJA

Katarina Vinković

Diplomski rad

**Integralne skale u prizemnom
atmosferskom sloju za buru**

Voditelj diplomskog rada: doc. dr. sc. Željko Večenaj

Ocjena diplomskog rada: _____

Povjerenstvo: 1. _____

2. _____

3. _____

Datum polaganja: _____

Zagreb, 2017.

Zahvaljujem se svojim mentorima, novom mentoru doc. dr. sc. Željku Večenaju te prethodnom mentoru prof. dr. sc. Branku Grisogonu, na vodstvu, pomoći i strpljenju tijekom cijelog procesa izrade ovog diplomskog rada.

Osobito se želim zahvaliti roditeljima na dugogodišnjoj potpori, strpljenu i razumijevanju.

Zahvaljujem se i svojim prijateljima bez kojih studentski dani ne bi toliko bili zabavni.

Sažetak

Mnogi numerički i klimatski modeli za prognozu vremena koriste prognostički oblik jednadžbe turbulentne kinetičke energije (TKE). Mjera disipacije TKE se parametrizira odgovarajućim omjerom TKE i takozvanom integralnom skalom duljine, što je otežano određenim numeričkim koeficijentom. U znanstvenoj zajednici ne postoji dogovor o jedinstvenoj formulaciji takve integralne skale. Stoga, u literaturi nalazimo različite oblike integralne skale. Međutim, one se najčešće izvode iz autokorelacijske funkcije i Fourierovog spektra komponenti brzine vjetra. To su, takozvane skale $1/e$ i skala prelaska nule te skala za koju normalizirani Fourierov spektar postiže maksimum.

Cilj ovog rada je procjena integralne skale turbulencije i pripadnog numeričkog koeficijenta, po prvi put, za buru. Za analizu koristimo podatke prikupljene „*WindMaster*“ ultrasoničnim anemometrima na visinama 2, 5 i 10 m, u neposrednoj blizini novog Masleničkog mosta, s čestinom uzrokovanja od 20 Hz. U razdoblju od 09. listopada 2015. do 09. listopada 2016. godine izdvojeno je 48 epizoda bura u trajanju od otprilike 1206 sati. Tako veliki set podataka nam omogućava procjenu navedene integralne skale i numeričkog koeficijenta u svrhu testiranja parametrizacije TKE i disipacije TKE u prizemnom sloju za buru.

Takozvana skala $1/e$ se pokazala najboljom za procjenu integralne skale turbulencije za buru. U konačnici, na temelju analiziranih podataka uočeno je znatno odstupanje numeričkog koeficijenta za buru u odnosu na vrijednosti korištenih u znanstvenoj zajednici, koje predlažu npr. Cuxart i sur. (2006), to nam ostavlja prostora za daljnja detaljnija istraživanja u budućnosti.

Ključne riječi: autokorelacijska funkcija, bura, integralne skale, TKE, turbulencija

Integral scales in the surface boundary layer for bora flows

Abstract

Many NWP and climate models use prognostic turbulence kinetic energy (TKE) equation. TKE dissipation ratio is parameterized via suitable ratio of TKE and so-called integral length scale for turbulence, which is weighted by a certain numerical coefficient. The scientific community does not have unique agreement on formulation of integral turbulence scales. Therefore, in literature we find various forms of those integral scales. However, usually they are derived from autocorrelation functions and Fourier spectra of wind speed components. These are the so-called 1/e and zero crossing scales and the scale at which a normalized Fourier spectra achieve their maximum value.

The aim of this study is to evaluate integral turbulence scales and the related coefficient, for the first time for bora flows. For the analysis we used data collected with „*WindMaster*“ ultrasonic anemometers at heights 2, 5 and 10 m, close to new Maslenica bridge, with a frequency sampling of 20 Hz. In the period from 09 October 2015 to 09 October 2016 recorded were 48 bora events with cumulative duration of 1206 hours. Such a large dataset gives us an opportunity to evaluate integral turbulence scales and the related numerical coefficient to test the parametrization of the TKE dissipation rate for the atmospheric surface boundary layer in bora flows.

So-called 1/e scale proved to be the best estimate for the integral turbulence scale. At the end, based on the analyzed dataset, it has been observed a significant disagreement of the numerical coefficient for bora flows compared with values used in the literature, proposed by e.g. Cuxart et al. (2006). This leaves us space for further studies in future.

Keywords: autocorrelation function, bora, integral scales, TKE, turbulence

SADRŽAJ

1 UVOD	1
2 TEORIJSKI PREGLED	5
2.1. Definicije turbulencije	5
2.2. Prognostička TKE jednadžba i parametrizacija disipacije TKE.....	8
2.3. Određivanje disipacije TKE (ϵ)	10
2.4. Integralne skale	12
2.5. Skala maksimuma Fourierovog spektra komponenti brzina	15
2.6. Parametar stabilnosti.....	17
3 OPIS MJERENJA	18
3.1. Lokacija meteorološkog stupa	18
3.2. Definiranje bure	20
3.3. Kontrola kvalitete podataka.....	24
4 REZULTATI.....	26
4.1. Parametar stabilnosti.....	26
4.2. TKE	27
4.3. Disipacija TKE.....	28
4.5. Skala maksimuma Fourierovog spektra longitudinalne komponente brzine	31
4.6. Numerički koeficijent ($C\epsilon$)	33
5 ZAKLJUČAK	34
6 LITERATURA	35
7 POPIS SLIKA	38
8 POPIS TABLICA	38

1 UVOD

Osim ugodnijih povjetaraca, na Jadranu su prisutni i snažniji vjetrovi koji dosežu orkanske razmjere, poput bure. Bura je relativno hladan, olujni vjetar koji puše na mahove iz sjeveroistočnog kvadranta u zavjetrini priobalnih planina od Trsta do Dubrovnika pa i južnije, kada se relativno hladna sjeveroistočna struja zraka obrušava preko Dinarida (npr. Yoshino, 1976; Makjanić, 1978). Brzina puhanja uvjetovana je kompleksnom orografijom terena čija visina i širina rastu od sjeverozapada prema jugoistoku, što ujedno predstavlja i smjer pružanja Dinarida. Stoga, najjača bura javlja se na mjestima gdje je smjer puhanja vjetra dominantno okomit na planinski lanac uz blage navjetrinske i strme zavjetrinske strane te niz planinske prijevoje (npr. Vratnik 700 m.n.v.). Olujni vjetar sličnog tipa prisutan je i na drugim mjestima u svijetu: Japan, Rusija, Kurdistan, Island, Austrija, Meksiko, Stjenjak, itd. (npr. Makjanić, 1978) čime su istraživanja o buri globalno primjenjiva.

Iako je bura u prosjeku zimski vjetar (zbog svoje jačine i dugotrajnosti), javlja se tijekom cijele godine u trajanju od nekoliko sati do nekoliko dana, ovisno o dominantnim baričkim sustavima nad Jadranom te konfiguraciji istih nad većim dijelom europskog kontinenta. Prema tome, razlikujemo tri osnovna tipa bure (npr. Večenaj, 2005):

1. Anticiklonalna (jasna) bura – Prisutna kada se nad europskim kontinentom proteže prostrano polje visokog tlaka zraka (npr. Sibirski anticiklon), dok je nad Sredozemljem slabije izražena depresija, relativno dugotrajna i jaka.
2. Ciklonalna (mračna) bura – Nastaje kada je nad Sredozemljem izraženo polje sniženog tlaka (ciklona), a nad istočnim dijelom europskog kontinenta anticiklona. Praćena je oblačnim, kišnim čak i snježnim vremenom.
3. Frontalna bura – Posljedica je prodornog hladnog zraka koji se nalazi iza hladne fronte, može biti vrlo intenzivna, no ne traje dulje od dan - dva.

Ako izuzmemo orkansko djelovanje vjetra praćeno osjetom hladnoće, poznato je kako bura ima povoljan biometeorološki utjecaj na ljude (npr. Večenaj, 2005). Pročišćava i bistri

atmosferu pa je vidljivost nakon bure izvrsna, a vrijeme sunčano i vedro. No, s druge strane, bura mehaničkim djelovanjem, sušenjem tla i stvaranjem posolice onemogućava razvoj vegetacije na izloženim sjevernim dijelovima pojedinih otoka sjevernog Jadrana (Krk, Pag, Rab, itd.). Bura je uzrok poteškoćama u svim granama gospodarske djelatnosti, osobito u prometu (cestovni, pomorski i zračni), zbog svog orkanskog i mahovitog djelovanja.

Postoji veliki opus radova na temu bure, međutim, turbulentne karakteristike bure su i dalje relativno neistražene. Razlog tomu je nedostatak odgovarajućih mjerenja nužnih za proučavanje turbulencije, koja se odvija na mikroskali. To su takozvana *in situ* visokofrekventna mjerenja brzine vjetra i temperature u prostoru i vremenu (redom npr. avionska mjerenja i mjerenja na meteorološkim stupovima). Krajem prošlog te početkom ovog stoljeća provedeno je nekoliko projekata u sklopu kojih su izvršena *in situ* visokofrekventna mjerenja brzine vjetra i temperature duž dijela istočne obale Jadrana.

Početkom 21. stoljeća izvršena su *in situ* mjerenja brzine vjetra na samoj obali u Senju, u jednoj točki 13 m iznad tla. Za prikupljanje podataka korišten je šalični anemometar s čestinom uzrokovanja od 1 Hz, u razdoblju od 1. prosinca 2001. do 31. siječnja 2002. godine. Belušić i sur. (2004) koriste navedena mjerenja i pokazuju prisustvo pulsacija u buri na periodima između 1 i 10 minuta. Nazočnost pulsacija povezuju sa slabim brzinama vjetra u gornjoj troposferi te kritičnog sloja s velikim brzinama vjetra u donjoj troposferi. U kritičnom sloju se odvija određena valna dinamika koja uz pojavu takozvane Kelvin – Helmholtzove nestabilnosti može dovesti do pucanja samih valova što proizvodi pulsacije. Nadalje, na istom setu podataka, Belušić i sur. (2006) proučavaju svojstva turbulencije bure u smislu njezine lokalnosti i nelokalnosti. Pokazali su da Taylorova hipoteza o „zamrznutoj turbulenciji“, nužna za prijelaz iz vremenske u prostornu domenu, vrijedi za odabrane slučajeve. Preliminarno su pokazali da za slučaj lokalne turbulencije (za periode kraće od 1 min) vrijedi linearan odnos između standardne devijacije i srednje brzine vjetra, što odgovara teorijskim predviđanjima (npr. Stull, 1988).

Sljedeći set podataka mjeren je u istoj točki u Senju, ali su ovaj put podaci prikupljeni ultrazvučnim anemometrom koji je mjerio 3D brzinu vjetra s čestinom uzrokovanja od 4 Hz. Mjerenja su trajala od ožujka 2004. do lipnja 2006. godine. Belušić i Klaić (2006) su koristili navedeni set podataka kako bi ocijenili uspješnost rekonstrukcije odabranih događaja bure numeričkim modelom. Demonstrirali su kako vrijednost turbulentne kinetičke energije

(TKE) u buri može postići vrijednost i od 30 Jkg^{-1} . Nadalje, Večenaj i sur. (2010) isti set podataka koriste za prvu procjenu disipacije TKE za buru i računanje parametrizacijske skale turbulencije koja se koristi u numeričkim prognostičkim i klimatskim modelima. Zaključili su da ta skala raste s porastom brzine vjetra.

Zbog energije vjetra javlja se potreba za visokofrekventnim mjerenjima brzine vjetra na srednjem Jadranu. U tu svrhu, prikupljena su visokofrekventna mjerenja na Pometenom brdu, na meteorološkom stupu, ultrazvučnim anemometrima na visinama 10, 20 i 40 m iznad tla s čestinom uzrokovanja od 5 Hz. Potom su višestruko analizirani u sklopu diplomskih te znanstvenih radova. Magjarević (2011) procjenjuje period usrednjavanja za ljetnu buru srednjeg Jadrana na temelju mjerenja prikupljenih na Pometenom brdu, u blizini Dugopolja, u razdoblju od 30. travnja 2010. do 29. srpnja 2010. godine. Na temelju dobivenih rezultata ukazuje na mogućnost da period usrednjavanja za turbulenciju ljetne bure nije jedinstven na ovoj lokaciji, već da ovisi o brzini vjetra, trajanju bure i visini iznad tla. Zaključuje da za sporiju i kraću buru taj period izrazito varira, dok za veće brzine i dugotrajnije bure pokazuje sklonost konvergiranja prema određenoj vrijednosti.

Babić (2013) se u svom radu bavi proučavanjem turbulentnih tokova bure. Koristio je podatke s Pometenog brda, za razdoblje od 1. siječnja do 31. ožujka 2011. godine. Na temelju lokalnog minimuma u Fourierovim spektrima snage komponenti brzine i tzv. ogiva¹ turbulentnih tokova, odredio je vremensku skalu usrednjavanja u iznosu od 15 min. Pokazao je kako su turbulentni tokovi izrazito promjenjivi s visinom, osobito za jače bure. Nadalje, zaključio je da nije ispravno koristiti jedinstvenu parametrizacijsku skalu duljine turbulentnih vrtloga u numeričkim modelima, s obzirom da ona raste s visinom iznad tla. Lepri i sur. (2014) proučavaju prizemne profile brzine ljetne bure na Pometenom brdu, u razdoblju od travnja 2010. do lipnja 2011. godine. Uočili su opadanje eksponenta potencijanskog zakona za brzinu vjetra i duljine hrapavosti, te porast brzine trenja s porastom brzine vjetra kod bure. Zaključili su da profili za male brzine vjetra nalikuju profilima za urbana područja, dok profili za veće brzine vjetra nalikuju onima za ruralna područja. Po prvi put, utvrdili su kako se promatrani profili srednje brzine vjetra uz dominantni smjer bure dobro slažu s aproksimacijama potencijanskog i logaritamskog zakona.

¹ Ogiva je definirana kao kumulativni integral kospektra kinematičkog turbulentnog toka impulsa ili topline.

Na osnovu izoliranog slučaja bure, koji je trajao od 24. srpnja do 27. srpnja 2010. godine, u trajanju od 62 h na Pometenom brdu, Lepri i sur. (2015) proučavaju prizemnu turbulenciju ljetne bure. Utvrdili su kako intenzitet turbulencije nije toliko osjetljiv na promjenu srednje brzine, kako se do tada smatralo. Nadalje, pokazali su kako duljina skale turbulencije raste s porastom srednje brzine vjetra. Povećanjem visine iznad tla, intenzitet turbulencije opada, dok parametrizacijska skala veličine turbulentnih vrtloga raste, što je u skladu s teorijom.

Babić i sur. (2016) koriste mjerenja s Pometenog brda, u razdoblju od 1. siječnja do 31. ožujka 2011. godine, u svrhu proučavanja turbulentnih tokova bure tijekom zimskih mjeseci. Po određivanju perioda usrednjavanja od 15 min, analizirali su vertikalne tokove impulsa i topline za 17 epizoda bura u promatranom razdoblju. Došli su do novih spoznaja za brzine vjetra veće od 12 ms^{-1} . Prvo, noću vertikalni tok topline na visini od 10 m je pozitivan, umjesto negativan. Drugo, vertikalni profili impulsa su veći na nivou od 22 m, nego na nivoima 10 i 40 m, za vrijeme približno neutralne do slabo stabilne termalne stratifikacije. Treće, vertikalni profili turbulentnog prijenosa impulsa pokazuju znatnu ovisnost o smjeru vjetra, uz odsustvo vertikalnog transporta impulsa za najveće brzine vjetra kod bure. Procjenu vertikalnih profila impulsa dodatno su potkrijepili pomoću „*Variable – Interval Time Averaging*“ (VITA) metode, koja je po prvi put korištena za analizu podataka bure.

Na osnovu iznad navedenog pregleda dosadašnjih istraživanja mikroskalnih turbulentnih karakteristike bure, primjećujemo kako je i dalje prisutan problem parametrizacije turbulencije u numeričkim modelima. Mnogi numerički i klimatski modeli koriste prognostičku jednadžbu TKE, u kojoj je disipacija TKE parametrizirana odgovarajućim omjerom TKE i integralne skale duljine te pripadnim numeričkim koeficijentom.

Cilj ovog rada je procijeniti integralne skale duljine te pripadni numerički koeficijent, po prvi put za buru. Dobivene rezultate za buru želimo usporediti s vrijednostima pronađenim u literaturi, a koji se danas koriste u numeričkim modelima.

2 TEORIJSKI PREGLED

2.1. Definicije turbulencije

Razumijevanja turbulentnih karakteristika toka fluida jedan je od najintragantnijih problema u klasičnoj i kvantnoj fizici. Činjenica je da je većina tokova fluida turbulentna te istovremeno, u mnogima slučajevima predstavlja dominantnu problematiku, na svim makroskopskim skalama – od krvožilnog i respiratornog sustava živih bića, do geofizičkih i astrofizičkih fenomena, koji uključuju unutrašnjost planeta, oceana i atmosfere. Problematikom turbulencije bavili su se neki od najvećih fizičara 19. i 20. stoljeća, no i dalje u potpunosti ne razumijemo mehanizam nastanka turbulencije, niti možemo s pouzdanošću predvidjeti turbulentno ponašanje.

Turbulencija je uočena kao posebno ponašanje strujanja još prije petstotinjak godina, gdje ju Leonardo Da Vinci opisuje na poprilično moderan način:

„ ...velike stvari može okretati samo veliki vrtlog, dok male stvari i mali i veliki vrtlog. “

Zapaženi fenomen je nazvao „*turbolenza*“, odakle ujedno i potječe naziv za turbulenciju. Često se susrećemo s činjenicom da ne postoji dobra definicija turbulencije pa su mnogi znanstvenici skloni odricanju formalne definicije u korist intuitivnih karakterizacija. Jedan od poznatijih je Richardson i njegova definicija iz 1922. godine:

*„Veliki vrtlozi djeluju na male vrtloge, na način da ih hrane energijom srednjeg toka;
Manji vrtlozi djeluju na još manje vrtloge, i sve tako do viskoznosti. “*

To odražava ideju, da mehanička energija koju sadrži fluid koji se giba, prolazi kroz „*kaskade*“ pri čemu se prenosi na sve manje skale dok u konačnici ne biva disipirana (tj. pretvori se u toplinsku energiju) na molekularnoj razini.

Nadalje, T. von Karman (1938) citira definiciju turbulencije od G.I. Taylor - a:

„Turbulencija je nepravilno gibanje, koje se općenito javlja u fluidima, plinovima ili tekućinama, kada teku uz čvrstu prepreku ili čak kada susjedne struje istog fluida teku pored ili jedna iznad druge. “

Zatim Hinze (1959), u jednom od najčešće korištenog priručnika o turbulenciji, daje sljedeću definiciju turbulencije:

„Turbulentno gibanje je nepravilno stanje toka, u kojem mnoge varijable pokazuju slučajne promjene u prostori i vremenu, na način da možemo raspoznati njihove razlike u statističkom smislu.“

Možemo primijetiti kako ni jedna od ovih definicija ne daje precizan opis karakteristika turbulentnog strujanja, u smislu prognožiranja, hoće li se i kada turbulencija pojaviti te u kojoj mjeri i intenzitetu. Taj nedostatak preciznosti u određenoj mjeri doprinosi nerazumijevanju problematike turbulencije u potpunosti.

Chapman and Tobak (1985) opisuju evoluciju razumijevanja turbulencije preko tri područja koja se međusobno preklapaju, a to su, *statističko, strukturno i determinističko*, čime su doprinijeli preciznijem definiranju turbulencije:

„Turbulencija je svako kaotično rješenje 3D Navier-Stokesovih jednačbi, koje je osjetljivo na početne uvijete te se javlja kao posljedica nestabilnosti kod laminarnog strujanja s porastom parametra bifurkacije.“

Iako je ova definicija još uvijek pomalo nejasna, posjeduje elemente koji dopuštaju detaljnije proučavanje turbulentnog strujanja. Prvo, navodi Navier – Stokesove jednačbe, čija rješenja dovodi u vezu s turbulencijom, dok u prethodnim definicijama one nisu bile eksplicitno naznačene. Drugo, zahtjeva da strujanje fluida bude „*kaotično*“ tj. nepravilno, kao i u prijašnjim definicijama, no determinističko, a ne slučajno. Treće, traži da turbulencija bude trodimenzionalna, što je u skladu s klasičnim pretpostavkama (npr. Tennekes i Lumley (1972) generiranje turbulencije pripisuju rastezanju vrtloga u tri prostorne dimenzije).

Znamo, da je „*kaotičnost*“ sadržana i u jednodimenzionalnim (1D) i dvodimenzionalnim (2D) rješenjima Navier – Stokesovih jednačbi, gdje je bitno napomenuti kako „*kaotično*“ strujanje nije nužno uvijek turbulentno, iako je povezano Navier – Stokesovim jednačbama.

Znači, u konačnici se može zaključiti da turbulentno strujanje ima sljedeće odlike:

1. neorganizirano, kaotično, naizgled slučajno strujanje;
2. nemoguće ga je ponoviti (tj. osjetljivo je na početne uvijete);
3. odvija se na dovoljno velikoj prostornoj i vremenskoj skali tako da je i najmanja skala dovoljno velika da ispunjava hipotezu kontinuuma;
4. prisutna je pojačana difuzija (miješanje) i disipacija (oba pod utjecajem molekularne viskoznosti);
5. trodimenzionalno strujanje, ovisno o vremenu i podložno rotaciji (vrtloženju);
6. sporadičnost u vremenu i prostoru.

Danas, za proučavanje turbulencije još uvijek koristimo statistički pristup s dekompozicijom, na koju primjenjujemo Reynoldsovo usrednjavanje (npr. Stull, 1988). Odnosno, moguće je polja osnovnih meteoroloških elemenata A (poput polja tlak, potencijalne temperature, komponenti brzine vjetra, itd.) razložiti na sporo promjenjivo srednje polje \bar{A} te na brzo varirajuće turbulentne fluktuacije a' tog istog polja:

$$A = \bar{A} + a' . \quad (1.1)$$

Srednjak perturbacija po definiciji iščezava ($\bar{a'} = 0$). Iz toga proizlazi da produkt srednjaka i fluktuacija nekih dviju veličina A i B , primjenom Reynoldsovog usrednjavanja, također iščezavaju ($\overline{\bar{B}a'} = 0$). Stoga, vrijedi da je:

$$\overline{AB} = \overline{(\bar{A} + a')(\bar{B} + b')} = \bar{A}\bar{B} + \overline{a'b'} . \quad (1.2)$$

Na osnovu iznad opisanog postupka, primjećujemo da o samoj turbulenciji govore varijance ($\overline{a'^2}$) i kovarijance ($\overline{a'b'}$) tih perturbacija. Nadalje, u ovom radu svu analizu radimo na 30-minutnim intervalima, iz razloga što oni sadrže najviše turbulentne energije. Istovremeno, sortiranje vremenskih nizova u 30-minutne intervale je svojevrsan visokopropusni filter koji uklanja utjecaj strujanja velike skale (npr. Večenaj i DeWekker, 2015).

2.2. Prognoštička TKE jednađba i parametrizacija disipacije TKE

TKE je jedna od najvažnijih varijabli u statističkom opisu turbulentnog strujanja. Ona predstavlja mjeru intenziteta turbulencije (npr. Stull 1988), a njena inačica koju koristimo je TKE po jedinici mase:

$$\frac{TKE}{m} = \bar{e} = \frac{1}{2}(\overline{u'^2} + \overline{v'^2} + \overline{w'^2}). \quad (2.1)$$

Mnogi numerički prognoštički i klimatološki modeli u današnje vrijeme koriste informacije o promjeni TKE u vremenu. Ta promjena TKE sažeta je u prognoštičku TKE jednađbu, koja u Einstenovoj notaciji poprima sljedeći oblik:

$$\frac{\partial \bar{e}}{\partial t} + \bar{u}_j \frac{\partial \bar{e}}{\partial x_j} = \delta_{i3} \frac{g}{\Theta} \overline{u'_i \Theta'} - \overline{u'_i u'_j} \frac{\partial \bar{u}_i}{\partial x_j} - \frac{\partial \bar{u'_j e}}{\partial x_j} - \frac{1}{\bar{\rho}} \frac{\partial \bar{u'_i p'}}{\partial x_i} - \varepsilon. \quad (2.2)$$

U (2.2) g predstavlja akceleraciju sile teže, Θ potencijalnu temperaturu, $\bar{\rho}$ srednju gustoću česti zraka te ε disipaciju TKE molekularnom viskoznošću u toplinu.

Ako koordinatni sustav postavimo u smjeru srednjeg vjetrova, pretpostavimo horizontalnu homogenost te zanemarimo supsidenciju, tada dolazimo do takozvanog 1D oblika TKE jednađbe (2.3), koja prati njene promjene u vremenu uzrokovane isključivo promjenom turbulencije po vertikali (npr, Stull 1988):

$$\underbrace{\frac{\partial \bar{e}}{\partial t}}_I = \underbrace{\frac{g}{\Theta} \overline{w' \Theta'}}_{II} - \underbrace{\overline{u' w'} \frac{\partial \bar{u}}{\partial z}}_{III} - \underbrace{\frac{\partial \bar{w' e}}{\partial z}}_{IV} - \underbrace{\frac{1}{\bar{\rho}} \frac{\partial \bar{w' p'}}{\partial z}}_V - \varepsilon. \quad (2.3)$$

Članovi prognoštičke TKE jednađbe (2.3) su redom:

- I lokalna promjena TKE;
- II termičko – uzgonska produkcija/destrukcija;
- III dinamičko – mehanička produkcija smicanjem;
- IV vertikalni transport TKE vertikalnom turbulentnom brzinom;
- V transport TKE perturbacijama tlaka.

ε je važan član u (2.3), a samim time i u parametrizaciji turbulencije. Odnosno, numerički i klimatski modeli za prognozu vremena koji koriste prognostički oblik TKE s tzv. redom zatvaranja 1.5 (obzirom da jednačbe za opis turbulencije nisu zatvorene), parametriziraju viskoznu disipaciju ε na način (npr. Bougeault i Lacarrere, 1989; Cuxart i sur., 2006; Costa i sur., 2011):

$$\varepsilon = C_\varepsilon \frac{e^{3/2}}{L_\varepsilon}, \quad (2.4)$$

gdje ε dijagnosticiramo preko izraza (2.4). Pritom je C_ε numerički koeficijent, $e = TKE$, a L_ε integralna skala duljine koja se također na neki način parametrizira u numeričkim modelima (npr. Blackadarova skala). To je ujedno jedna od najslabijih točaka parametrizacije turbulencije (npr. Yamada i Mellor, 1982).

Cilj ovog rada je odrediti ε , e i L_ε iz mjerenja, obzirom da u konačnici želimo pronaći koeficijent C_ε za buru, čiji iznos je zadan u literaturi kao raspon vrijednosti između 0,07 i 0,8 (npr. Cuxart i sur., 2006). No, u ovom trenutku ne znamo koja integralna skala duljine je ona prava o čemu ćemo detaljnije u poglavlju 2.4.

2.3. Određivanje disipacije TKE (ε)

Za procjenu viskozne disipacije (ε) koristili smo *metodu inercijalne disipacije* (engl. *Inertial Dissipation Method – IDM*; npr. Tennekes i Lumley, 1972), obzirom da je ε član u (2.2) i (2.3) za TKE koji ne možemo izravno izračunati.

Za mjerenja prikupljena na *in situ* način u vremenu, IDM metoda zahtjeva valjanost Taylorove hipoteze o „zamrznutoj turbulenciji“. Taylorovu hipotezu možemo primijeniti ako je omjer standardne devijacije (σ_M) i srednjaka horizontalne (longitudinalne) komponente brzine (\bar{u}) u promatranom vremenskom intervalu manji od 0,5 (npr. Stull, 1988):

$$\frac{\sigma_M}{\bar{u}} < 0,5 . \quad (2.5)$$

Kolmogorov je prvi dao ideju o postojanju inercijalnog potpodručja, koji razdvaja energijsko i disipacijsko područje spektra. Na osnovu dimenzijske analize predlaže da spektar energije $E(k)$ u inercijskom potpodručju bude proporcionalan $\varepsilon^{2/3} k_1^{-5/3}$ (npr. Kolmogorov, 1941):


$$F_u(k_1) = \alpha_u \varepsilon^{2/3} k_1^{-5/3} , \quad (2.6)$$

gdje $F_u(k_1)$ predstavlja Fourierov spektar gustoće snage longitudinalne komponente brzine vjetra, α_u Kolmogorovu konstantu (uzimamo vrijednost 0,53; npr. Večenaj i sur., 2010), ε viskoznu disipaciju, dok je k_1 valni broj (indeks 1 znači da je u longitudinalnom smjeru).

To je zapravo, dobro poznati -5/3 potencijski zakon u inercijalnom potpodručju te sve upućuje na činjenicu da bi turbulencija trebala biti izotropna u tom području. Pritom, izotropnost podrazumijeva da je polje brzine neovisno o rotaciji i položaju osi koordinatnog sustava. Iako se izotropnost ne odnosi na vrtloge u energijskom dijelu spektra, možemo pretpostaviti kako je za strukture na malim skalama izotropnost učinkovita. Ako je prisutna lokalna izotropnost u inercijalnom potpodručju, imamo sljedeću vezu između Fourierovih spektara snage komponenti brzine vjetra (npr. Kaimal i Finnigan, 1994):

$$F_v(k_1) = F_w(k_1) = (4/3)F_u(k_1). \quad (2.7)$$

Slika 2.1. shematski prikazuje iznad navedene odnose. Vidimo kako u logaritamskoj reprezentaciji Fourierovi spektri snage komponenata brzine vjetra prate nagib pravca s koeficijentom smjera $-5/3$ unutar inercijalnog potpodručja na čemu počiva bit IDM metode. Postojanje inercijalnog potpodručja u spektrima nije uvijek jasno. U svrhu procijene inercijalnog potpodručja promatramo omjer Fourierovih spektara snage transverzalne (vertikalne) i longitudinalne komponente brzine.



Slika 2.1. Idealizirani prikaz Fourierovih spektara komponenti brzine vjetra u logaritamskoj reprezentaciji, uz nagib pravca s koeficijentom smjera od $-5/3$ i omjerom $4/3$ između transverzalne i longitudinalne komponente brzine (Preuzeto: Kaimal i Finnigan, 1994).

Ako omjeri vertikalne i longitudinalne komponente brzine teže iznosu $4/3$ (progresivno za sve više frekvencije), uz $-5/3$ potencijski zakon, onda možemo reći da inercijalno potpodručje postoji. Nadalje, logaritmiranjem (2.6), slijedi:

$$\log F_u(k_1) = -\frac{5}{3} \log(k_1) + \log(\alpha_u \varepsilon^{2/3}). \quad (2.8)$$

Daljnjim grupiranjem i sređivanjem prethodnog izraza dolazimo do relacije za viskoznu disipaciju:

$$\varepsilon = \left(\frac{k_1^{5/3} F_u(k_1)}{\alpha_u} \right)^{3/2}. \quad (2.9)$$

Kako radimo s podacima u obliku vremenskih nizova, primjenom Taylorove hipoteze (2.5), koristimo alternativni izraz koji u sebi sadrži frekvenciju umjesto valnog broja, zbog tranzicije iz prostorne (valnih brojeva) u vremensku (frekvencija) domenu uz IDM metodu dolazimo do konačnog izraza za viskoznu disipaciju:

$$\varepsilon = \frac{2\pi}{\bar{u}} \left(\frac{f^{5/3} F_u(f)}{\alpha_u} \right)^{3/2}. \quad (2.10)$$

2.4. Integralne skale

Mnogi praktični inženjerski problemi traže analizu autokorelacijske funkcije te su rješenja tih problema jednostavnija kada ne ovise o apsolutnom vremenu. Stoga, autokorelacija za funkciju bez srednjaka $u(t)$, u vremenskim trenutcima t_1 i t_2 glasi (npr. Kundu i Cohen, 2002):

$$R(t_1, t_2) \equiv \overline{u(t_1)u(t_2)}. \quad (2.11)$$

Kod stacionarnog procesa statistika ne ovisi o početnom trenutku. Zamjenom početnog trenutka s t_1 , izraz (2.11) prelazi u $u(0)u(t_2 - t_1) = u(0)u(\tau)$, gdje je τ razlika vremena. Njegovu korelaciju možemo pisati kao $u(t)u(t + \tau)$, koja je samo funkcija od τ , dok je t apsolutni vremenski trenutak. Tada autokorelacija stacionarnog procesa glasi:

$$R(\tau) = \overline{u(t)u(t + \tau)}. \quad (2.12)$$

Pomoću izraza (2.11) definiramo normaliziranu autokorelacijsku funkciju kao:

$$r(\tau) = \frac{\overline{u(t)u(t + \tau)}}{\overline{u^2}}, \quad (2.13)$$

gdje je $\overline{u^2}$ srednje kvadratno odstupanje (varijanca). Nadalje, za bilo koju funkciju $u(t)$ možemo pokazati Schwartzovu nejednakost:

$$\overline{u(t_1)u(t_2)} \leq \left[\overline{u^2(t_1)} \right]^{\frac{1}{2}} \left[\overline{u^2(t_2)} \right]^{\frac{1}{2}}. \quad (2.14)$$

Ona je zapravo analog pravilu da skalarni produkt dva vektora ne može biti veći od njihovog umnoška modula (tj. $|u \cdot v| \leq |u||v|$). Za stacionarni proces, srednje kvadratno odstupanje ne ovisi o vremenu, tako da je desna (2.14) jednaka $\overline{u^2}$ iz čega slijedi:


$$r \leq 1. \quad (2.15)$$

Očito, $r(0) = 1$. Idealizirani primjer autokorelacijske funkcije prikazan je na slici 2.2., u normalnim uvjetima r ide u 0 kako $\tau \rightarrow \infty$, pošto proces postaje nekoreliran nakon dugo vremena, obzirom da je turbulencija uvelike „*slučajna*“ pojava.

To nam dozvoljava da definiramo integral skale vremena T za turbulenciju:

$$T = \int_0^{\infty} r(\tau) d\tau. \quad (2.16)$$

T predstavlja vrijeme u kojem je proces $u(t)$ koreliran sam sa sobom. Drugim riječima, T je mjera „*pamćenja*“ procesa.



Slika 2.2. Prikaz autokorelacijske funkcije i veza s integralnom skalom vremena T. Lijevo: Prikaz skale $L_{1/e}$. Desno: Prikaz područja integracije skale $L_{1/e_{int}}$.

Taylorova hipoteza o „zamrznutoj turbulenciji“ nam omogućava prijelaz iz vremenske u prostornu domenu, preko transformacije $x = \bar{u}T$. Stoga, na osnovu mjerenja komponenti brzine te opisane transformacije definiramo integralnu skalu duljine $L_\alpha = (L_u, L_v, L_w)$ (npr. Kaimal i Finnigan, 1994), koju izvodimo iz integralne skala vremena $T_\alpha = (T_u, T_v, T_w)$. Tada integralna skala duljine longitudinalne komponente brzine glasi:

$$L_u = \bar{u}T_u = \bar{u} \int_0^\infty r_u(\tau) d\tau = \bar{u} \int_0^\infty \frac{\overline{r'(t)r'(t+\tau)}}{\sigma_u^2} d\tau, \quad (2.17)$$

analogno vrijedi za L_v i L_w . U (2.17) \bar{u} predstavlja srednju brzinu vjetra, $r_u(\tau)$ autokorelacijsku funkciju, vremenski usrednjene $\overline{r'(t)r'(t+\tau)}$ fluktuacije polja brzine te σ_u^2 srednje kvadratno odstupanje (varijanca). Ako je $r_u(\tau)$ eksponencijalna funkcija, integralna skala vremena je vrijednost od τ za $r_u(\tau) = 1/e \approx 0,37$, gdje je $e \approx 2,72$ konstanta, odnosno, baza prirodnog logaritma. Integralnu skalu duljine možemo definirati kao najdužu korelaciju između dva turbulentna vrtloga.

Jednadžba (2.17) uključuje određivanje integrala preko beskonačne domene, no kako je autokorelacijska funkcija konačna, dolazimo do pitanja: *Na koji način je najbolje definirati područje integracije?*

U literaturi pronalazimo različite načine određivanja integralne skale iz autokorelacijske funkcije, no četiri najčešće korištene su:

1. Skala $L_{1/e}$ – Uzimamo vrijednost $T_{1/e}$;
2. Skala L_{1/e_int} – Integriramo površinu ispod autokorelacijske funkcije do $T_{1/e}$;
3. Skala L_0 – Uzimamo vrijednost T_0 (tj. prvi prelazak nule);
4. Skala L_{0_int} – Integriramo površinu ispod autokorelacijske funkcije od ishodišta do skale prelaska nule, odnosno L_0 .

Nakon što smo iznad definirali integralne skale, potrebno je odrediti koja od njih je najpogodnija za izračun koeficijenta C_ε iz (2.4). Stoga, potreban nam je kriterij koji definiramo u sljedećem poglavlju.

2.5. Skala maksimuma Fourierovog spektra komponenti brzina

Kraj produkcijskog dijela spektra osjetljiv je na „onečišćenja“ iz dugoročnih trendova prisutnih u podacima, koji mogu biti posljedica težinskih valova, dnevnih varijacija te ostalih utjecaja. U odsustvu tih trendova, (2.6) za $F_u(k_1)$ postaje konstanta kako $k_1 \rightarrow 0$, kao posljedica jednodimenzionalne interpretacije trodimenzionalnog turbulentnog spektra. Prepoznavanje maksimuma energije u takvim spektrima, zapravo je teško. Stoga, za realističniji prikaz maksimuma i minimuma raspodjele energije turbulencije koristimo spektar otežan valnim brojem $k_1 F_u(k_1)$.

Spektar na frekvencijama koji sadrži turbulenciju možemo aproksimirati jednim od dva analitička izraza (npr. Kaimal i Finnigan, 1994):

$$\frac{k_1 F_\alpha(k_1)}{\sigma_\alpha^2} = \frac{A(k_1/k_{1m})}{1 + B(k_1/k_{1m})^{5/3}}, \quad (2.18)$$

$$\frac{k_1 F_\alpha(k_1)}{\sigma_\alpha^2} = \frac{C(k_1/k_{1m})}{[1 + D(k_1/k_{1m})]^{5/3}}. \quad (2.19)$$

Tu α predstavlja komponente brzine u, v ili w , dok A, B, C i D su pripadne konstante, a indeks m označava valni broj k_1 za koji spektar ima maksimum. U analizi bure kraj Maslenice, koristili smo (2.19) te smo za svaki 30-minutni interval bure računali pripadne konstante C i D. Spektar otežan valnim brojem nazivamo još i logaritamskim spektrom, pošto predstavlja varijancu po jedinici logaritamskog valnog intervala.

Obzirom da se naši proračuni nalaze u domeni frekvencije, potrebno je učiniti prijelaz iz prostorne u frekventnu skalu, na način $k_1 = 2\pi f/\bar{u}$ (preko Taylorove hipoteze), gdje je f frekvencija. Ako promotrimo na primjeru u komponente brzine, odnos otežanog Fourierovog spektra gustoće snage u domeni valnog broja i frekvencijskoj domeni je sljedeći (npr. Kaimal i Finnigan, 1994):

$$\int_0^\infty F_u(k_1) dk_1 = \sigma^2 = \int_0^\infty S_u(f) df, \quad (2.20)$$

pri čemu vrijedi:

$$\frac{2\pi}{\bar{u}} F_u\left(\frac{2\pi f}{\bar{u}}\right) = S_u(f), \quad (2.21)$$

Izraz (2.21) vrijedi za bilo koju formu f , uključujući i bezdimenzionalnu frekvenciju $n = fz/\bar{u}$, koju koristimo u prizemnom sloju atmosfere. Stoga, $k_1 F(k_1)$, $fS_u(f)$ i $nS_u(n)$ predstavljaju istu numeričku vrijednost ostavljajući nam slobodu pri odabiru frekventne skale na apscisi. Analogno tome, (2.19) poprima oblik:

$$\frac{fS_u(f)}{u_*^2} = \frac{Cn}{[1 + Dn]^{5/3}}, \quad (2.22)$$

koji smo koristili u ovom radu za izračun skale maksimalnog Fourierovog spektra longitudinalne komponente brzine normaliziran kvadratom brzine trenja (u_*^2).


Nas zapravo zanima veza između integralnih skala i skale maksimalnog Fourierovog spektra longitudinalne komponente brzine. Za teorijski oblik autokorelacijske funkcije aproksimirane izrazom $r_u(\tau) = e^{-\tau/T_\alpha}$, Lumley i Panofsky (1964) navode da za neutralnu stratifikaciju vrijedi:

$$(f_m)_\alpha = \frac{1}{2\pi T_\alpha}, \quad (2.23)$$

gdje je $f_m (= 1/T_m)$ frekvencija maksimalnog Fourierovog spektra (slika 2.3.), a T_α integralna skala vremena. U našem slučaju α je longitudinalna komponenta brzine (u) te (2.23) postaje:

$$\frac{(T_m)_u}{T_u} = 2\pi. \quad (2.24)$$

Izraz (2.24) je kriterij da iz integralnih skala pronađemo najpogodniju skalu za procjenu koeficijenta C_ε . Kako bismo izbjegli spektre iz statički stabilnog i nestabilnog područja, ograničavamo se na kvazineutralne 30-minutne intervale, a njih određujemo preko parametra stabilnosti.



Slika 2.3. Prikaz normaliziranog statički neutralnog Fourierovog spektra u , v i w komponenti brzine u prizemnom sloju. Crvena isprekidana linija označava maksimum Fourierovog spektra longitudinalne komponente brzine (Preuzeto i modificirano: Kaimal i Finnigan, 1994).

2.6. Parametar stabilnosti

Jedan od indikatora statičke stabilnosti prizemne atmosfere je parametar stabilnosti z/L , gdje je z visina iznad tla, a L Obukhovljeva duljina.

Obukhovljeva duljina je karakteristična skala za debljinu dinamičkog podsloja (npr. Obukhov, 1946), odnosno, sloja u kojem zanemarujemo utjecaj osnovne stratifikacije (npr. Monin i Yaglom, 1973). S pretpostavkom kako parametri g/θ_0 (g akceleracija sile teže, θ_0 temperatura na površini), u_* brzina trenja i $q/C_p\rho$ (q kinematički tok topline, C_p specifična toplina, ρ gustoća zrak) opisuju turbulenciju dinamičkog podsloja iznad sloja hrapavosti, definirano je:

$$L = -\frac{\bar{\theta}}{gk} \frac{u_*^3}{\overline{(w'\theta'_0)}}. \quad (2.25)$$

Članovi Obukhovljeve duljine su $\bar{\theta}$ srednja temperatura, $\overline{(w'\theta'_0)}$ vertikalni turbulentni tok topline i k je von Karmanova konstanta (iznosi 0,4).

Nadalje, definiramo parametar statičke stabilnosti (z/L), koji je prikladan za prizemni sloj, kao omjer visine z i Obukhovlje duljine L :

$$\frac{z}{L} = -\frac{(g/\bar{\theta})\overline{(w'\theta'_0)}}{u_*^3/kz}, \quad (2.26)$$

pri čemu vrijedi:

$$\frac{z}{L} > 0 \quad \text{stabilna stratifikacija};$$

$$\frac{z}{L} = 0 \quad \text{neutralna stratifikacija};$$

$$\frac{z}{L} < 0 \quad \text{nestabilna stratifikacija}.$$

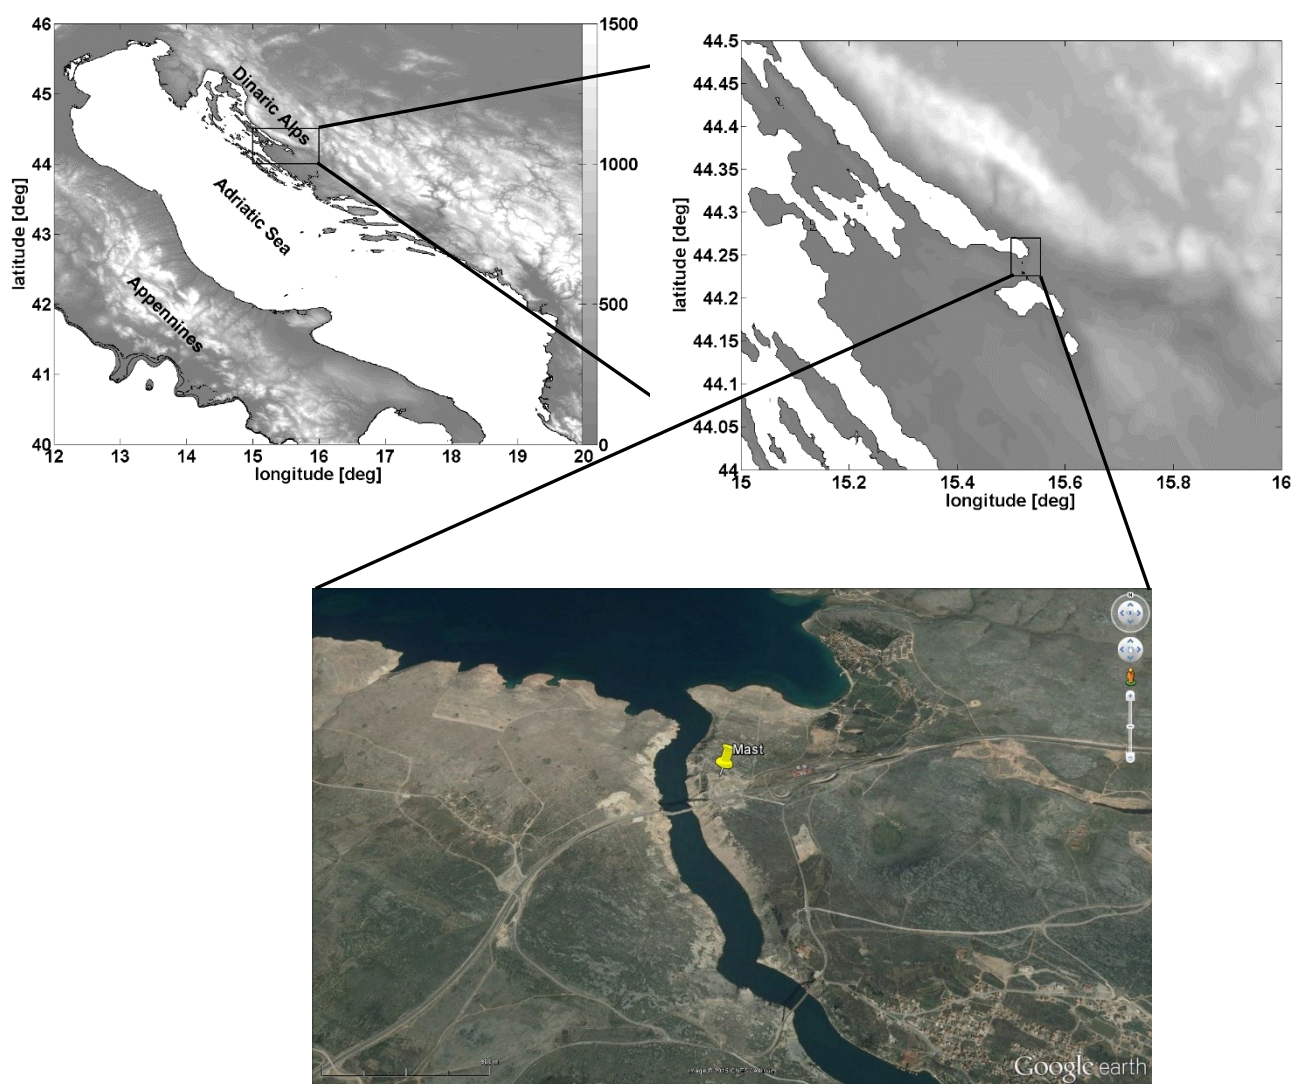
Parametar stabilnosti je pogodan za naša mjerenja, obzirom da mjerimo ultrazvučnu temperaturu zraka, čija apsolutna vrijednost nije pouzdana, dok fluktuacije jesu. Iz (2.25) vidljivo je da za pozitivne vrijednosti $\overline{(w'\theta'_0)}$ (nestabilna stratifikacija) imamo negativne vrijednosti parametra stabilnosti (z/L), dok za negativne vrijednosti $\overline{(w'\theta'_0)}$ (stabilna stratifikacija) imamo pozitivne vrijednosti parametra stabilnosti (z/L).

U ovom radu ćemo se ograničiti na 30-minutne intervale s vrijednostima $-0,1 \leq z/L \leq 0,1$ koje smatramo kvazineutralnim intervalima.

3 OPIS MJERENJA

3.1. Lokacija meteorološkog stupa


Rad se temelji na mjerenjima turbulencije vjetera, u vremenskom razdoblju od 09.10.2015. do 09.10.2016. godine, na 10 m visokom meteorološkom stupu, postavljenom oko 200 m sjeveroistočno od Masleničkog mosta na autocesti A1, Zagreb – Split (slika 3.1.).



Slika 3.1. Lijevo: Prikaz Jadranskog mora. Crni pravokutnik označava područje Velebitskog kanala. Desno: Uvećano područje dijela Velebitskog kanala. Crni pravokutnik predstavlja okolicu novog Masleničkog mosta. Dolje: Uvećana okolica novog Masleničkog mosta. Žuto označava poziciju 10 m meteorološkog stupa.

Cilj je bio prikupiti kvalitetna mjerenja visoke rezolucije u vremenu i po visini, u svrhu istraživanja mikroskalnih karakteristika turbulencije bure u prvih 10 m iznad tla, koja su presudna za sve oblike prometa, turizam, poljoprivredu, transport i disperziju onečišćenja te korištenje energije vjetra.

Na visinama 2, 5 i 10 m iznad tla, na meteorološkom stupu su instalirani po jedan „*WindMaster Pro*“ ultrasonični anemometar proizvođača *Gill Instruments*, koji su mjerili 3D brzinu vjetra (u, v, w) te soničnu temperaturu (T_s) s frekvencijom uzrokovanja od 20 Hz. Zbog specifičnosti vlastitog koordinatnog sustava anemometra s apscisom orijentiranom prema sjeveru i ordinatom prema zapadu (slika 3.2.), pri analizi podataka bilo je potrebno izvršiti transformaciju u standardni desni koordinatni sustav ($u = -V_+, v = U_+, w = W_+$, uvažavajući oznake na sl. 3.2.).



Slika 3.2. Prikaz ultrasoničnog anemometra korištenog za prikupljanje podataka na Maslenici.
a) Koordinatni sustav anemometra, gledan odozgo. b) Prikaz postavljenog anemometra na vertikalni stup, s naznakom smjera vertikalne komponente brzine.

Anemometri su serijski bili spojeni na „*Datalogger CR3000*“ proizvođača *Campbell Scientific* čija je uloga sinkronizacija, obrada i zapisivanje mjerenja. Cijeli sustav bio je neovisan, obzirom da je napajan sunčevom energijom. Visine 2, 5 i 10 m su odabrane s ciljem što vjernijeg reproduciranja logaritamskog profila vjetra, tipičnog za horizontalan atmosferski prizemni sloj. Meteorološki stup i okolni teren prikazani su na slici 3.3. Podloga u neposrednoj blizini meteorološkog stupa je karakteristična za priobalje Jadrana, uz prevladavajući biljni pokrov, u obliku gariga (niska, prorijeđena, svijetla poluzimzelena šikara) i makije (teško prohodna, gusta tvrdolisna šikara) te kamenjar.

Zbog mjerenja visoke rezolucije, od 20 Hz, i nivoa (2, 5 i 10 m) na kojima su prikupljeni podaci, ovo je jedinstven i najdetaljniji skup obrađenih podataka o vjetru do sada na jednom mjestu u Hrvatskoj, u sklopu projekta *CATURBO*.



Slika 3.3. Prikaz meteorološkog stupa. a) Ultrasonični anemometri postavljeni na visinama 2, 5 i 10 m. Dodatno, senzor za temperaturu, relativnu vlažnosti i tlak postavljeni su na nivou od 2 m. b) Prikaz baze meteorološkog stupa sa solarnim napajanjem u prvom planu. Prednja solarna ploča postavljena je u smjeru jugozapada, a stražnja u smjeru jugoistoka.


3.2. Definiranje bure

Obzirom da smo raspolagali s mjerenjima visoke rezolucije, analiza podataka je zahtijevala sljedeći pristup. Početni set podataka sadržavao je nešto manje od 630 720 000 mjerenja (uslijed manjih prekida) na tri nivoa. Kako je riječ o jednogodišnjem zapisu mjerenja, umjesto uobičajene prvotne kontrole kvalitete podataka, sirove podatke smo grupirali u dnevne zapise (slika 3.4.), s ciljem jednostavnije analize podataka.


Nadalje, u ovom radu, za definiranje bure koristili smo sljedeće kriterije:

1. 10-minutni srednjaci smjera vjetra moraju biti unutar raspona kuteva $[0^\circ, 90^\circ]$, što odgovara sjeveroistočnom (NE) smjeru puhanja bure;
2. vjetar tako definiran mora puhati minimalno u trajanju od 6 h.

Na osnovu opisanih kriterija izdvojili smo 48 epizoda bure (tablica 1.), u ukupnom trajanju od otprilike ≈ 1206 h te smo na izdvojenim epizodama proveli kontrolu kvalitete podataka, o čemu ćemo detaljnije u poglavlju 3.3. Najbrži opaženi udar bure iznosio je 64,75 m/s (bura #7).



Slika 3.4. Dnevni zapis mjerenja, u razdoblju od 07.03. do 16.03.2016. godine, na koje smo primijenili kriterij za definiranje bure. Na apscisi je vrijeme u 10-minutnim srednjacima, dok na lijevoj ordinati (plavo) je horizontalna brzina (m/s), a na desnoj ordinati (zeleno) smjer vjetra (stupnjevi). Crvenom bojom su uokvireni početak i kraj epizoda bure #18 (gore) i #19 (dolje).



Slika 3.5. Uvećani prikaz najduže epizode bure #19 (tablica 1.).

Tablica 1. Osnovna statistika za 48 izdvojenih epizoda bure u razdoblju od 09.10.2015. do 09.10.2016. godine na Maslenici. Na visinama 2, 5 i 10 m dani su vrijeme početaka i kraja epizode bure, duljina trajanja (ΔT) te srednja (v_{sred}) i maksimalna (v_{max}) horizontalna brzina.

KRONOLOGIJA BURE					10 m		5 m		2 m	
#	GOD [y.]	START [d.m. h:min]	KRAJ [d.m. h:min]	ΔT [h:min]	v_{sred} [m/s]	v_{max} [m/s]	v_{sred} [m/s]	v_{max} [m/s]	v_{sred} [m/s]	v_{max} [m/s]
1.	2015.	10.10. 09:09	11.10. 06:59	21:50	12,14	36,50	10,03	38,13	8,28	34,35
2.	2015.	21.10. 14:48	24.10. 02:03	59:15	10,14	51,67	7,97	45,02	7,00	44,26
3.	2015.	28.10. 19:34	29.10. 14:00	18:26	4,71	16,13	4,16	14,71	3,71	14,53
4.	2015.	29.10. 15:03	01.11. 17:50	74:47	6,13	26,29	5,24	26,64	4,35	24,93
5.	2015.	21.11. 15:10	22.11. 01:29	10:09	8,83	35,81	7,52	33,56	6,12	31,55
6.	2015.	22.11. 08:26	22.11. 22:19	13:53	6,37	24,81	5,37	21,52	4,35	21,66
7.	2015.	26.11. 02:39	28.11. 00:49	46:10	18,43	63,98	15,31	64,75	12,73	54,44
8.	2015.	10.12. 02:49	10.12. 11:29	8:40	18,37	47,67	14,69	45,53	12,42	43,16
9.	2015.	30.12. 10:39	30.12. 19:49	9:10	10,72	33,64	9,03	31,37	7,35	29,27
10.	2016.	16.01. 00:59	17.01. 03:49	26:50	18,44	56,33	14,50	57,74	12,26	56,34
11.	2016.	17.01. 14:59	18.01. 07:19	16:20	20,43	52,02	16,07	56,97	13,56	54,64
12.	2016.	21.01. 13:09	22.01. 05:09	16:00	7,66	22,13	6,44	21,20	5,17	20,29
13.	2016.	03.02. 22:49	04.02. 16:39	17:50	19,18	49,26	15,76	51,29	12,87	45,63
14.	2016.	16.02. 13:29	17.02. 02:29	13:00	10,74	32,52	9,22	30,81	7,80	30,00
15.	2016.	24.02. 05:59	24.02. 15:39	9:40	10,18	35,27	8,57	35,76	6,97	32,90
16.	2016.	26.02. 06:39	26.02. 16:59	10:20	7,97	25,69	6,83	24,53	5,59	24,49
17.	2016.	04.03. 00:49	04.03. 08:49	8:00	15,66	39,38	12,05	37,74	10,31	34,91
18.	2016.	08.03. 22:49	10.03. 15:39	40:50	9,17	32,85	7,66	30,78	6,33	31,13
19.	2016.	12.03. 08:19	15.03. 07:29	71:10	17,07	49,37	13,89	45,34	11,69	44,98
20.	2016.	15.03. 16:29	17.03. 10:19	41:50	7,71	22,38	6,56	21,66	5,38	20,65
21.	2016.	22.03. 11:59	24.03. 22:59	59:00	16,58	59,02	13,72	57,54	11,36	52,70
22.	2016.	19.04. 04:29	19.04. 20:09	15:40	14,28	41,49	11,95	38,93	9,83	39,73
23.	2016.	19.04. 23:59	20.04. 08:29	8:30	11,77	37,10	9,97	35,35	8,11	32,08
24.	2016.	20.04. 13:49	20.04. 22:29	8:40	6,64	25,95	5,78	22,90	4,80	23,32

KRONOLOGIJA BURE					10 m		5 m		2 m	
#	GOD [y.]	START [d.m. h:min]	KRAJ [d.m. h:min]	ΔT [h:min]	v_{sred} [m/s]	v_{max} [m/s]	v_{sred} [m/s]	v_{max} [m/s]	v_{sred} [m/s]	v_{max} [m/s]
25.	2016.	24.04. 09:29	25.04. 16:59	31:30	14,54	41,93	12,15	41,55	9,94	40,36
26.	2016.	15.05. 10:59	16.05. 10:49	23:50	12,05	35,02	9,81	34,35	8,26	32,45
27.	2016.	20.05. 01:59	20.05. 13:49	11:50	9,59	31,56	8,01	28,53	6,68	30,20
28.	2016.	21.05. 08:49	21.05. 23:59	15:10	6,71	29,78	5,70	28,02	4,65	25,93
29.	2016.	23.06. 16:49	24.06. 01:49	11:00	7,64	20,60	6,44	20,53	5,17	21,07
30.	2016.	27.06. 17:49	28.06. 13:09	19:20	8,83	35,24	7,44	30,21	6,03	28,71
31.	2016.	03.07. 17:59	04.07. 11:09	17:10	8,73	30,77	7,42	31,13	6,07	28,28
32.	2016.	06.07. 23:19	07.07. 09:49	10:30	7,78	24,38	6,67	24,32	5,42	23,48
33.	2016.	14.07. 21:59	17.07. 03:49	66:10	20,82	61,85	16,45	57,28	13,93	49,80
34.	2016.	01.08. 18:59	02.08. 11:49	16:50	9,26	31,25	7,84	29,14	6,33	29,40
35.	2016.	06.08. 02:19	06.08. 13:29	11:10	12,47	32,58	10,54	31,41	8,59	32,10
36.	2016.	06.08. 14:49	08.08. 07:09	40:20	14,88	49,16	12,03	44,35	10,23	42,38
37.	2016.	10.08. 23:39	12.08. 03:59	28:20	10,49	34,49	8,86	33,52	7,19	32,55
38.	2016.	21.08. 22:29	22.08. 18:49	20:20	13,16	41,86	10,61	38,89	9,03	37,09
39.	2016.	23.08. 00:09	24.08. 01:29	25:20	14,08	55,32	11,27	57,36	9,53	52,67
40.	2016.	24.08. 04:09	26.08. 01:49	45:40	9,91	38,35	8,37	33,23	6,78	31,60
41.	2016.	30.08. 06:39	31.08. 05:59	23:20	8,74	23,89	7,46	23,26	6,03	21,80
42.	2016.	06.09. 15:09	07.09. 22:29	31:20	12,69	39,18	10,67	38,26	8,73	35,37
43.	2016.	08.09. 17:49	10.09. 00:49	31:00	8,98	31,20	7,58	30,04	6,14	27,92
44.	2016.	10.09. 01:39	10.09. 13:19	11:40	7,02	23,18	6,06	23,50	5,02	22,31
45.	2016.	20.09. 11:29	22.09. 01:09	37:40	6,64	20,60	5,66	19,71	4,59	18,55
46.	2016.	22.09. 09:19	22.09. 21:19	12:00	7,08	23,29	6,01	22,21	4,85	22,60
47.	2016.	27.09. 15:59	28.09. 04:29	12:30	8,73	23,35	7,41	22,23	5,95	22,14
48.	2016.	04.10. 20:49	05.10. 22:19	25:30	12,07	46,51	9,81	43,73	8,35	43,38

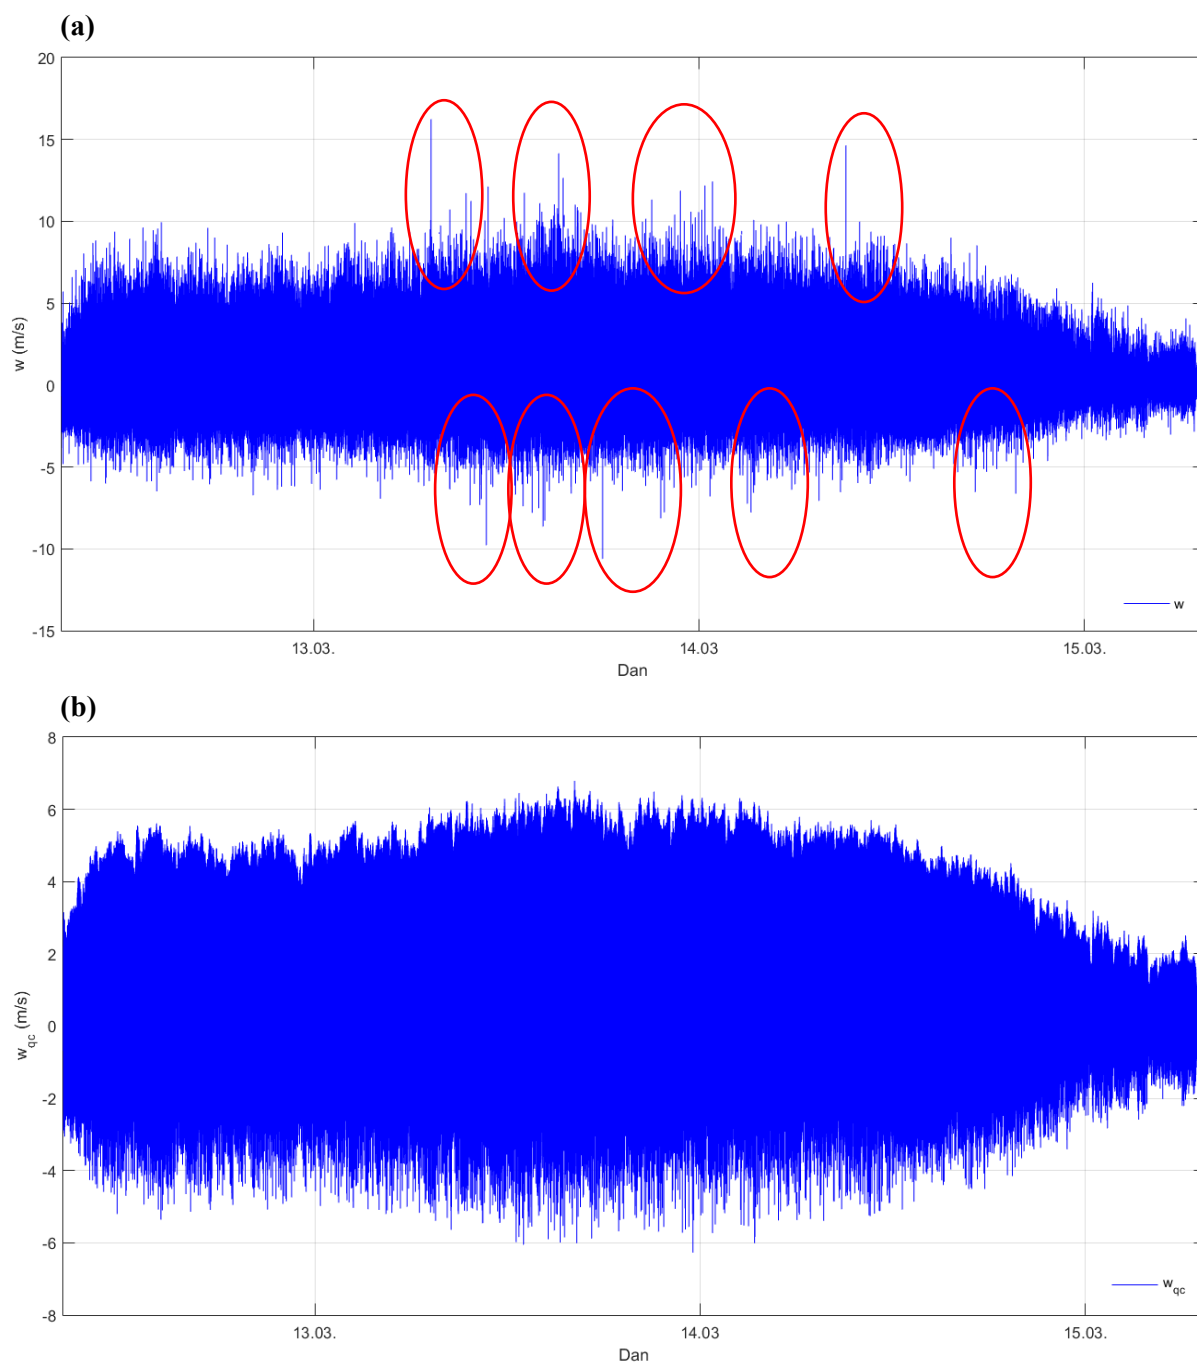
3.3. Kontrola kvalitete podataka

Upotrebom digitalnih instrumenata prisutna je mogućnost pogrešnog očitavanja na instrumentu. Uzroci mogu biti razne prirode, kao na primjer, kvar na instrumentu, sustavne pogreške, slučajne pogreške pa čak i preosjetljivost uređaja na vremenske uvijete, poput oborine i grmljavina. Stoga je potrebno izvršiti kontrolu kvalitete podataka na izdvojenim epizodama bure (npr. Pandžić, 2002).

Kao što možemo uočiti na slici 3.6., pojavljuju se određeni podaci koji odstupaju od „uobičajenog“ ponašanja niza, kao nagli individualni skokovi kod vertikalne komponente brzine (w) bure (epizoda #19). Takve podatke je bilo potrebno ukloniti automatskom programskom procedurom, zbog velikog broja podataka.

„Loše“ podatke prepoznamo na način da se radi o maksimalno tri uzastopne točke u nizu, čija amplituda je nekoliko standardnih devijacija veća od srednjaka (npr. Vickers i Mahrt, 1997). Definiran je prozor duljine 5 minuta, što se pomičemo u nizu za 1 podatak, za svaku izdvojenju epizodu bure (njih 48). Odnosno, u početnom trenutku je izdvojen podatak koji je sumnjiv, ako njegova amplituda u prozoru od 5 minuta je veća od 3,5 standardne devijacije računajući od srednjaka prozora. Ako pronađemo četiri ili više takvih uzastopnih vrijednosti, to ne smatramo podatkom koji odskače iz niza te interpoliramo izdvojene podatke kako bi vremenski nizovi bili potpuni.

Nakon provedene kontrole kvalitete podataka, pristupamo daljnjoj analizi podataka, odnosno izračunu TKE, Fourierovog spektra, disipacije TKE, integralnih skala, skale maksimalnog Fourierovog spektra longitudinalne komponente brzine te samog numeričkog koeficijenta C_ε .



Slika 3.6. Prikaz vertikalne komponente brzine (w) za najdužu epizodu bure (tablica 1., bura #19). a) Sirovi podaci vertikalne komponente brzine (w). b) Vertikalna komponenta brzine (w_{qc}) nakon uklanjanja podataka (označeni crvenom bojom), koji odstupaju od globalnog ponašanja niza.


4 REZULTATI

Za svaki 30-minutni interval bure rotiran je koordinatni sustav na način da je os x (apscisa) paralelna s longitudinalnom komponentom brzine. Rotacija koordinatnog sustava omogućava testiranje logaritamskog profila vjetra u prizemnom sloju atmosfere te je početni koordinatni sustav rotiran za $(270 - \alpha)^\circ$. U poglavlju 3.3. dan je osnovni statistički opis izdvojenih 48 epizoda bure na visinama 2, 5 i 10 m iznad tla (tablica 1.).

4.1. Parametar stabilnosti

Izdvojene epizode bura su sortirane u 30-minutne blokove, radi usrednjavanja kovarijanci i varijanci potrebnih za daljnju analizu podataka.

Za svaki 30-minutni blok na visinama 2, 5 i 10 m iznad tla izračunata je lokalna Obukhovljeva duljina L (relacija (2.25)) gdje je potom svaka visina bezdimenzionirana pripadnom Obukhovljevom duljinom (relacija (2.26)), poznatije kao parametar stabilnosti (slika 4.1.). Svrha ovog postupka je odrediti stabilnosti prizemne atmosfere (npr. Babić i sur., 2016).




Slika 4.1. Histogrami parametra stabilnosti (z/L) na visinama 2, 5 i 10 m iznad tla, za izdvojene epizode bure na Maslenici.

Dobiveni rezultati pokazuju kako je lokalna atmosfera uglavnom neutralna, za trajanja bure, obzirom da se najviše vrijednosti grupira oko nule (slika 4.1.). To možemo objasniti dobrom izmiješanošću površinskog sloja uslijed jakog vertikalnog smicanja vjetra.

Neutralnim 30-minutnim intervalima smatramo sve intervale za koje vrijedi da je $-0,1 \leq z/L \leq 0,1$ i ti 30-minutni intervali su uzeti u obzir za daljnju analizu. Dodatno, iz analize smo izbacili sve intervale koji ne zadovoljavaju kriterij Taylorove hipoteze o „zamrznutoj turbulenciji“ te sve 30-minutne intervale čiji Fourierovi spektri komponenti brzina ne zadovoljavaju omjer 4/3. Na taj način, za analizu nam je ostalo 1894 30-minutnih intervala na 2-m nivou, 1385 intervala na 5-m nivou i 681 interval na 10-m nivou.

4.2. TKE

TKE je izračunata na 30-minutnim intervalima za sve izdvojene epizode bure prema (2.1), te je njen kumulativni niz prikazan na slici 4.2.



Slika 4.2. Prikaz TKE na svim visinama za izdvojene epizode bure na osnovu jednogodišnjeg zapisa mjerenja. Crvena krivulja odnosi se na visinu 2 m, zelena krivulja na 5 m te plava na 10


Promatrajući TKE za izdvojene epizode bure uočavamo njezin porast s visinom (tablica 2.), što je u skladu s teorijom za prvih 10 m visine iznad tla (npr. Tennekes i Lumley, 1972).

Tablica 2. Osnovna statistika za TKE izdvojenih epizoda bure, u razdoblju od 09.10.2015. do 09.10.2016. godine na Maslenici. Na visinama 2, 5 i 10 m dane su vrijednosti srednje (TKE_{sred}) i maksimalne (TKE_{max}) TKE.

$[m^2 s^{-2}]$	2 m	5 m	10 m
TKE_{sred}	7,02	7,21	8,33
TKE_{max}	27,16	34,28	40,62

4.3. Disipacija TKE

Prije bilo kakve daljnje obrade podataka, bilo je potrebno provjeriti da li su kriteriji iz poglavlja 2.3. ispunjeni u smislu postojanja inercijalnog potpodručja za izdvojene epizode bure. Na slici 4.3. prikazan je jedan 30-minutni interval bure za koji ćemo ispitati gore navedene kriterije.




Slika 4.3. Logaritamski prikaz spektra snage longitudinalne komponente brzine vjetra. Crvena isprekidana linija predstavlja pravac $y = -5/3x$ u log-log obliku, dok dvije crne isprekidane linije predstavljaju interval unutar kojeg je uvjet na nagib najbolje zadovoljen.

Za procjenu inercijalnog potpodručja promatrali smo nagib spektra snage po komponentama brzine te omjere tih spektara. Ako su ispunjeni kriteriji za izotropnost turbulencije, odnosno, da nagibi približno prate pravac koeficijenta smjera $-5/3$, tada je opravdano pretpostaviti postojanje inercijalnog potpodručja, što je zadovoljeno u našem slučaju. Interval unutar kojeg je uvjet na nagib najbolje zadovoljen (između 0.3 i 6 Hz) naznačen je isprekidanom crnom linijom na slici 4.3.

4.4. Integralne skale

Kako integralne skale izvodimo iz autokorelacijske funkcije, potrebno je odrediti najoptimalnije područje integracije. Izraz (2.17) uključuje integral preko beskonačne domene, odnosno, obuhvaća cijelu domenu dostupnih mjerenja te time nije pogodan za analizu homogene izotropne turbulencije (iako predstavlja autokorelacijsku funkciju).

Stoga, u ovom radu koristimo četiri metode za određivanje područja integracije (definirane u poglavlju 2.4.) kako bi i ujedno proučili njihov utjecaj na određivanju integralne skale duljine. Sa slike 4.4. na primjeru realne autokorelacijske funkcije uočavamo kako prva metoda ($L_{1/e}$) uzima vrijednost na x za koji $y = 1/e$, druga metoda (L_{1/e_int}) integrira površinu ispod krivulje od ishodišta do x za koji $y = 1/e$. Nadalje, treće područje integracije predstavlja vrijednost x za koji $y = 0$ tj. skala prelaska nule (L_0), dok u četvrtoj metodi (L_{0_int}) integriramo od ishodišta do skale prelaska nule (engl. zero crossing).




Slika 4.4. Prikaz realne autokorelacijske funkcije longitudinalne komponente vjetra. Prikaz određivanja područja integracije, odnosno, veza sa skalama $T_{1/e}$, T_{1/e_int} , T_0 i T_{0_int} .

Zatim, promatramo postoji li određena ovisnost između integralnih skala i srednje brzine vjetra, što je prikazano na slici 4.5.

Dodatno, izračunali smo i empirijsku integralnu skalu turbulentne duljine Λ (npr. Babić, 2013) i usporedili je s integralnim skala. Ta empirijska skala je jednostavni dimenzijski omjer TKE i ε (npr. Stull, 1988):

$$\Lambda = \frac{e^{3/2}}{\varepsilon}. \quad (4.1)$$



Slika 4.5. Integralne skale u ovisnosti o srednjoj brzini vjetra. Skale $L_{1/e}$, L_{1/e_int} , L_0 i L_{0_int} izvedene iz autokorelacijske funkcije, dok L_{0_int} je skala maksimalnog Fourierovog spektra longitudinalne komponente brzine, a Λ je empirijska integralna skala turbulentne duljine. Crna linija predstavlja integralne skale na 2 m, crvena na 5 m te plava na 10 m visine.


Na slici 4.5. možemo uočiti kako je prisutan veliki raspon kod integralnih skala, sve rastu s brzinom, istovremeno su različite, no neke su i slične.

Ukoliko detaljnije promotrimo skale $L_{1/e}$, L_{1/e_int} , L_{0_int} i L_{Su_max} , uočavamo kako prve dvije nakon postignutog maksimuma opadaju u ovisnosti o brzini, dok druge dvije nakon drugog maksimuma opadaju u ovisnosti o brzini. Kod integralne skale L_0 primjećujemo konstantan porast s brzinom (na sve tri visine), dok Λ empirijska integralna skala turbulentne duljine nakon postignutog minimuma opada u ovisnosti o brzini.

4.5. Skala maksimuma Fourierovog spektra longitudinalne komponente brzine

Obzirom da nije jednostavno prepoznati maksimum energije pri kraju produkcijskog dijela spektra, za realniji prikaz raspodjele energije turbulencije koristimo spektar otežan valnim brojem, odnosno frekvencijom.

Izraz (2.22) koristili smo za izračun skale maksimuma Fourierovog spektra. Slika 4.6. prikazuje primjer takvog spektra za jedan 30-minutni interval bure.




Slika 4.6. Primjer realne skale maksimuma Fourierovog spektra longitudinalne komponente brzine vjetra, na osnovu analize izdvojenih epizoda bure.

Kružići predstavljaju normalizirane vrijednosti Fourierovog spektra longitudinalne komponente vjetra otežanog pripadnom frekvencijom tj. lijevu stranu (2.22), dok crvena krivulja predstavlja najbolju prilagodbu, tj. desnu stranu (2.22). Crna isprekidana linija označava maksimum Fourierovog spektra $(T_m)_u$, koji nam je potreban u daljnjem izračunu kako bi u konačnici došli do iznosa koeficijenta C_ε za buru.

Po izračunu maksimuma Fourierovog spektra longitudinalne komponente brzine $(T_m)_u$ i pripadnih integralnih skala $(T_{1/e}, T_{1/e_int}, T_0, T_{0_int}, T_{Su_max}, \Lambda)$, promatramo njihov omjer s ciljem da bi otkrili koji od tih omjera je najbliži iznosu 2π iz izraza (2.24).

Na slici 4.7. uočavamo kako je željenom omjeru od 2π najbliža skala $T_{1/e}$. U daljnjoj analizi koristimo dominantnu skalu $T_{1/e}$.




Slika 4.7. Prikaz medijana omjera skale maksimalnog Fourierovog spektra longitudinalne komponente brzine i pripadnih integralnih skala. Crna isprekidana linija predstavlja željeni omjer skale, odnosno, 2π .

4.6. Numerički koeficijent (C_ε)

Konačno, iz (2.4) možemo procijeniti numerički koeficijent C_ε za buru (slika 4.8.), obzirom da smo odredili najpogodniju integralnu skalu, odnosno $L_{1/e}$ te iz mjerenja TKE i disipaciju TKE, na način:

$$C_\varepsilon = \frac{L_\varepsilon \varepsilon}{e^{3/2}}. \quad (4.2)$$



Slika 4.8. Prikaz numeričkog koeficijenta C_ε za buru.

Zapažamo porast numeričkog koeficijenta C_ε u ovisnosti o brzini dok ne postigne maksimum nakon čega uslijedi pad na sve tri visine (2, 5 i 10 m).

Usporedbom procijenjenog raspona vrijednosti koeficijenta C_ε , na temelju mjerenja, s očekivanim prema Cuxart i sur. (2006) uočavamo odstupanje, i to za jedan do dva reda veličine. Točnije, u literaturi se navodi raspon vrijednosti od 0,07 do 0,8 za koeficijent C_ε , dok je naš raspon vrijednosti od 1,7 do 3,5.

5 ZAKLJUČAK

Bura, osim na krajolik, ima i veliki utjecaj na mnoge ljudske djelatnosti (promet, turizam, poljoprivredu, itd.), osobito na sjevernom Jadranu gdje postiže najveće razmjere. Intenzivna istraživanja mikroskalnih karakteristika turbulencije bure na sjevernom Jadranu, u posljednjih 10-ak godina, ukazala su na potrebu za mjerenjima visoke rezolucije kao presudan faktor za analizu parametara turbulencije (TKE, disipacija TKE te ostali).

U ovom radu, analizirani su podaci prikupljeni ultrasoničnim anemometrima, u neposrednoj blizini novog Masleničkog mosta, na visinama 2, 5 i 10 m te po prvi puta s frekvencijom uzrokovanja od 20 Hz, u razdoblju od 09. listopada 2015. do 09. listopada 2016. godine. Primjenom kriterija za smjer i trajanje bure, izdvojeno je 48 epizoda bure, od kraćih u trajanju od nekoliko sati do višednevnih olujnih epizoda.

Glavni cilj ovog rada je bila procjena integralne skale L_α te numeričkog koeficijenta C_ε , po prvi put za buru. Kako ne postoji jedinstven dogovor oko definiranja područja integracije autokorelacijske funkcije prezentirana je detaljna analiza utjecaja učinka na ograničenje područja integracije autokorelacijske funkcije. Omjer skale maksimalnog Fourierovog spektra longitudinalne komponente brzine i skale $L_{1/e}$ najbliži je željenom iznosu od 2π . Procijenjena vrijednost koeficijenta C_ε znatno odstupa od očekivanih teorijskih vrijednosti, koje se koriste u numeričkim modelima. Razlog tome bi mogao biti nepostojanje jedinstvene definicije područja integracije autokorelacijske funkcije.

Zaključno, integralne skale su važna karakteristika strukture turbulencije. Moguće je izdvojiti integralnu skalu bilo iz numeričkih modela ili stvarnih podataka, međutim, trenutno ne postoji mehanizam za određivanje njezine točnosti. Budući da je ovo prvi rad u kojem su podaci brzine vjetra iskorišteni za procjenu integralne skale L_α te numeričkog koeficijenta C_ε za buru, bilo bi poželjno provesti isto i na drugim lokacijama vezano za buru, kao npr. sjevernom (Senj, Vratnik), srednjem (Pometeno brdo) te južnom Jadranu (Dubrovnik). Također, bilo bi dobro provesti analizu iz ovog rada i na drugim setovima podataka o turbulenciji vjetra te usporediti rezultate s rezultatima dobivenim za buru u ovom radu.

6 LITERATURA

Babić, N. 2013: Proučavanje turbulentnih tokova bure u navjetrini Splita. Diplomski rad, Geofizički odsjek PMF-a : 52 str.

Babić, N., Večenaj, Ž., Kozmar, H., Horvath, K. i Grisogono, B. 2016: On turbulent fluxes during strong winter bora events. *Boundary-Layer Meteorol.* : 331-350

Belušić, D., Pasarić, M. i Orlić, M. 2004: Quasi-periodic Bora gusts related to the structure of the troposphere. *Q. J. R. Meteorol. Soc.* : 1103-1121

Belušić, D., Pasarić, M., Pasarić, Z., Orlić, M. i Grisogono, B. 2006: A note on local and non-local properties of turbulence in the bora flow. *Meteorol. Z.* : 301-306

Belušić, D. i Klaić, Z., B. 2006: Mesoscale dynamics, structure and predictability of a severe Adriatic bora case. *Meteorol. Z.* : 157-168

Bougeault, P. i Lacarrere, P. 1989: Parametrization of Orography-Induced Turbulence in a Mesobeta-Scale Model. *Mon. Weat. Rev.* : 1872-1890

Chapman, G. T. i Tobak, M. 1985: Observations, Theoretical Ideas, and Modeling of Turbulent Flows — Past, Present and Future, in *Theoretical Approaches to Turbulence*, Dwyer et al. (eds), Springer-Verlag, New York : pp. 19-49

Costa, F. D., Otavio, C., Acevedo, Jose C. M. Mombach i Gervasio, A. Degrazia 2011: A Simplified Model for Intermittent Turbulence in the Nocturnal Boundary Layer. *Jou. Atm. Sci.* : 1714-1729

Cuxart, J., Holtslag, A. A., Beare, R. J., Bazile, E., Beljaars, A., Cheng, A., Conangla, L., Ek, M., Freedman, F., Hamdi, R., Kerstein, A., Kitagawa, H., Lenderink, G., Lewellen, D., Mailhot, J., Mauritsen, T., Perov, V., Schayes, G., Steeneveld, G-J., Svensson, G., Taylor, P., Weng, W, Wunsch, S. i Xu, K-M. 2006: Single-column model intercomparison for stably stratified atmospheric boundary layer. *Boundary-Layer Meteorol.* : 273-303

Hinze, J. O. 1959: Turbulence. McGraw-Hill, New York : 790 str.

Kaimal, J. C. i Finnigan, J. J. 1994: Atmospheric Boundary Layer Flows. Their Structure and Measurement, Oxford University Press, New York : pp. 33-63

Kundu, P.K. i Cohen, I. M. 2002: Fluid Mechanics. Second Edition, Academic Press, San Diego : pp. 502-504

Lepri, P., Kozmar, H., Večenaj, Ž. i Grisogono B. 2014: A summertime near-ground velocity profile of the Bora wind. Win. Struc. : 505-522

Lepri, P., Večenaj, Ž. Kozmar, H., i Grisogono B. 2015: Near-ground turbulence of the Bora wind in summertime. J. Wind Eng. Ind. Aerodyn. : 345-357

Lumley, J. L. i Panofsky, H. A. 1964: The Structure of Atmospheric Turbulence. Wiley-Interscience, New York : pp. 239

Makjanić, B. 1978: Bura, jugo, etezija. Prilozi poznavanja vremena i klime SFRJ, sv. 5 : pp. 1-43

Monin, A. S. i Yaglom, A. M. 1973: Statistical fluid mechanics: Mechanics of turbulence. Vol. 1., MIT Press, Cambridge, London : pp. 769

Magjarevic, V. 2011: Mikroskala ljetne bure na srednjem Jadranu. Diplomski rad, Geofizicki odsjek PMF-a : 30 str.

Obukhov, A. M. 1946: Turbulence in atmosphere with a non-uniform temperature. Trudy Inst. Theor. Geofiz. AN SSSR : pp. 95-115.

Pandžić, K. 2002: Analiza meteoroloških polja i sustava. Udžbenici Sveučilišta u Zagrebu : 314 str.

Richardson, L. F. 1922: Weather Prediction by Numerical Process. Cambridge University Press : 262 str.

Stull, R.B. 1988: An Introduction to Boundary Layer Meteorology. Kluwer Academic Publishers, Dordrecht, Nizozemska : 666 str.

Tennekes, H. i Lumley, J. L. 1972: A First Course in Turbulence. MIT Press, Cambridge : 300 str.

Večenaj, Ž., 2005: Procesi makrorazmjera kod olujnog vjetra u Dalmaciji. Diplomski rad, Grofizički odsjek PMF-a : 59 str.

Večenaj, Ž., Belušić, D. i Grisogono, B. 2010: Characteristics of the near-surface turbulence during a bora event. Ann. Geophys. : 155-163

Večenaj, Ž., De Wekker, S.F.J. i Grubišić, V. 2015: Near-surface characteristics of the turbulence structure during a mountain-wave event. Q. J. R. Meteorol. Soc. :1560-1571

Vickers, D. i Mahrt, L., 1997: Quality control and flux sampling problems for tower and aircraft data. J. Atmos. Oceanic Technol. : 512–526

von Karman, T. 1938: Some remarks on the statistical theory of turbulence. Proc. 5th Int. Congr. Appl. Mech., Cambridge, MA : 347 str.

Yamada, T. i Mellor, G.L., 1982: Development of a Turbulence Closure Model for Geophysical Fluid Problems. Rev. Geophys. Space Phy. : 851-875

Yoshino, M.M., 1976: Local wind bora. University of Tokyo Press, Tokyo : 289 str.

7 POPIS SLIKA

Slika 2.1. Prikaz Fourierovih spektara komponenti brzine vjetra.....	11
Slika 2.2. Prikaz autokorelacijske funkcije.....	13
Slika 2.3. Prikaz normaliziranog statički neutralnog Fourierovog spektra komponenti brzine u prizemnom sloju atmosfere.....	16
Slika 3.1. Lokacija meteorološkog stupa.....	18
Slika 3.2. Prikaz ultrasoničnog anemometra.....	19
Slika 3.3. Prikaz meteorološkog stupa.....	20
Slika 3.4. Prikaz dnevnih zapisa mjerenja.....	21
Slika 3.5. Prikaz najduže epizode bure.....	21
Slika 3.6. Prikaz vertikalne komponente brzine najduže epizode bure.....	25
Slika 4.1. Histogrami parametra stabilnosti.....	26
Slika 4.2. Prikaz TKE.....	27
Slika 4.3. Logaritamski prikaz spektra snage longitudinalne komponente brzine vjetra.....	28
Slika 4.4. Prikaz realne autokorelacijske funkcije.....	29
Slika 4.5. Prikaz integralnih skala.....	30
Slika 4.6. Prikaz realne skale maksimuma Fourierovog spektra longitudinalne komponente brzine vjetra.....	31
Slika 4.7. Prikaz omjera skale maksimalnog Fourierovog spektra longitudinalne komponente brzine vjetra i integralnih skala.....	32
Slika 4.8. Prikaz numeričkog koeficijenta za buru.....	33

8 POPIS TABLICA

Tablica 1. Osnovna statistika za 48 izdvojenih epizoda bure.....	22
Tablica 2. Osnovna statistika za TKE izdvojenih epizoda bure.....	28